


❖ ΜΗΧΑΝΕΣ ΔΙΑΝΥΣΜΑΤΙΚΗΣ ΣΤΙΡΙΞΗΣ (SUPPORT VECTOR MACHINES)

- Ο στόχος: Δοθέντων δύο γραμμικώς διαχωρίσιμων κλάσεων, να σχεδιαστεί ο ταξινομητής

$$g(\underline{x}) = \underline{w}^T \underline{x} + w_0 = 0$$

που αφήνει το **μέγιστο περιθώριο** από τις δύο κλάσεις



- Περιθώριο: Κάθε υπερεπίπεδο χαρακτηρίζεται από
- Την κατεύθυνση στο χώρο, δηλ., \underline{w}
 - Τη θέση του στο χώρο, δηλ., w_0
 - Για **ΚΑΘΕ** κατεύθυνση, \underline{w} επέλεξε το υπερεπίπεδο που **αφήνει την ΙΔΙΑ απόσταση** από τα **πλησιέστερα** σημεία από κάθε κλάση. Το περιθώριο είναι διπλάσιο αυτής της απόστασης.

- Η απόσταση ενός σημείου $\underline{\hat{x}}$ από ένα υπερεπίπεδο είναι

$$z_{\underline{\hat{x}}} = \frac{g(\underline{\hat{x}})}{\|\underline{w}\|}$$

- Κλιμάκωσε τα \underline{w} , \underline{w}_0 , έτσι ώστε στα εγγύτερα από κάθε κλάση η συνάρτηση διάκρισης είναι ± 1 :

$$|g(\underline{x})| = 1 \quad \{g(\underline{x}) = +1 \text{ για } \omega_1 \text{ και } g(\underline{x}) = -1 \text{ για } \omega_2\}$$

- Έτσι το **περιθώριο** δίνεται από τη σχέση

$$\frac{1}{\|\underline{w}\|} + \frac{1}{\|\underline{w}\|} = \frac{2}{\|\underline{w}\|}$$

- Επίσης, ισχύουν τα ακόλουθα

$$\underline{w}^T \underline{x} + w_0 \geq 1 \quad \forall \underline{x} \in \omega_1$$

$$\underline{w}^T \underline{x} + w_0 \leq -1 \quad \forall \underline{x} \in \omega_2$$

➤ SVM (γραμμικός) ταξινομητής

$$g(\underline{x}) = \underline{w}^T \underline{x} + w_0$$

➤ Ελαχιστοποίησε

$$J(\underline{w}) = \frac{1}{2} \|\underline{w}\|^2$$

➤ Υπό τους περιορισμούς

$$y_i(\underline{w}^T \underline{x}_i + w_0) \geq 1, \quad i = 1, 2, \dots, N$$

$$y_i = 1, \quad \text{for } \underline{x}_i \in \omega_1,$$

$$y_i = -1, \quad \text{for } \underline{x}_i \in \omega_2$$

➤ Αυτό γίνεται διότι ελαχιστοποιώντας το $\|\underline{w}\|$

το περιθώριο $\frac{2}{\|\underline{w}\|}$ μεγιστοποιείται

- Η παραπάνω είναι μία **διαδικασία τετραγωνικής βελτιστοποίησης (quadratic optimization task)** υπό τον περιορισμό ενός συνόλου γραμμικών ανισοτήτων. Οι **Karush-Kuhn-Tucker** συνθήκες, δηλώνουν ότι το **ελάχιστο** ικανοποιεί τις συνθήκες:

- (1) $\frac{\partial}{\partial \underline{w}} L(\underline{w}, w_0, \underline{\lambda}) = 0$

- (2) $\frac{\partial}{\partial w_0} L(\underline{w}, w_0, \underline{\lambda}) = 0$

- (3) $\lambda_i \geq 0, i = 1, 2, \dots, N$

- (4) $\lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1] = 0, i = 1, 2, \dots, N$

- Όπου $L(.,.,.)$ είναι η συνάρτηση **Lagrange**

$$L(\underline{w}, w_0, \underline{\lambda}) \equiv \frac{1}{2} \underline{w}^T \underline{w} - \sum_{i=1}^N \lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1]$$

➤ Η λύση: από τα παραπάνω, προκύπτει ότι

- $$\underline{w} = \sum_{i=1}^N \lambda_i y_i \underline{x}_i$$

- $$\sum_{i=1}^N \lambda_i y_i = 0$$

➤ Σχόλια:

- Οι πολ/στές Lagrange μπορεί να είναι είτε μηδέν είτε θετικοί. Έτσι,

$$- \quad \underline{w} = \sum_{i=1}^{N_s} \lambda_i y_i \underline{x}_i$$

όπου $N_s \leq N$ αντιστοιχεί στους θετικούς πολ/στές Lagrange

– Από τον περιορισμό (4) πιο πάνω, δηλ.,

$$\lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1] = 0, \quad i = 1, 2, \dots, N$$

τα διανύσματα που συνεισφέρουν στο \underline{w} ικανοποιούν

$$\underline{w}^T \underline{x}_i + w_0 = \pm 1$$

- Τα διανύσματα αυτά καλούνται **ΔΙΑΝΥΣΜΑΤΑ ΣΤΗΡΙΞΗΣ** και είναι τα **κοντινότερα διανύσματα**, από κάθε κλάση, προς τον ταξινομητή.
- Μετά τον υπολογισμό του \overline{W} το W_0 προσδιορίζεται από τις συνθήκες (4).
- Ο βέλτιστος ταξινομητής-υπερεπίπεδο μιας μηχανής διανυσματικής υποστήριξης είναι **ΜΟΝΑΔΙΚΟΣ**.

➤ Σχηματισμός Δυϊκού προβλήματος

- Το πρόβλημα των SVM είναι διατυπωμένο ως ένα κυρτό πρόβλημα προγραμματισμού (convex programming problem), με
 - Κυρτή συνάρτηση κόστους
 - Κυρτή περιοχή εφικτών (feasible) λύσεων
- Έτσι, η λύση μπορεί να προέλθει από το δυϊκό του πρόβλημα, δηλ.,

– Μεγιστοποίησε $L(\underline{w}, w_0, \underline{\lambda})$
 $\underline{\lambda}$

– Υπό τους περιορισμούς $\underline{w} = \sum_{i=1}^N \lambda_i y_i \underline{x}_i$

$$\sum_{i=1}^N \lambda_i y_i = 0$$

$$\underline{\lambda} \geq \underline{0}$$

- Συνδυάζοντας τα παραπάνω παίρνουμε

- Μεγιστοποίησε την $\left(\sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{ij} \lambda_i \lambda_j y_i y_j \underline{x}_i^T \underline{x}_j \right)$

- Υπό τους περιορισμούς


$$\sum_{i=1}^N \lambda_i y_i = 0$$

$$\underline{\lambda} \geq \underline{0}$$

➤ Σχόλια:

- Τα διανύσματα στήριξης εισέρχονται μέσω **εσωτερικών γινομένων**
- Παρότι η λύση, \underline{w} , είναι μοναδική, οι πολ/στές Lagrange ΔΕΝ ΕΙΝΑΙ.

➤ Non-Separable classes



Στην περίπτωση αυτή δεν υπάρχει υπερεπίπεδο, ώστε

$$\underline{w}^T \underline{x} + w_0 (><)1, \quad \forall \underline{x}$$

- Θυμηθείτε ότι το περιθώριο ορίζεται ως η απόσταση μεταξύ των δύο ακόλουθων υπερεπιπέδων

$$\underline{w}^T \underline{x} + w_0 = 1$$

και

$$\underline{w}^T \underline{x} + w_0 = -1$$

➤ Τα διανύσματα εκπαίδευσης ανήκουν σε μία από τρεις δυνατές κατηγορίες

- A. Διανύσματα **εκτός** περιθωρίου που ταξινομούνται **σωστά**, δηλ.,

$$y_i(\underline{w}^T \underline{x} + w_0) > 1$$

- B. Διανύσματα **εντός** περιθωρίου, που είναι **σωστά** ταξινομημένα, δηλ.,

$$0 \leq y_i(\underline{w}^T \underline{x} + w_0) < 1$$

- C. Διανύσματα **λανθασμένα ταξινομημένα**, i.e.

$$y_i(\underline{w}^T \underline{x} + w_0) < 0$$

- Όλες οι παραπάνω περιπτώσεις μπορούν να αναπαρασταθούν από

$$y_i(\underline{w}^T \underline{x} + w_0) \geq 1 - \xi_i$$

- A. $\rightarrow \xi_i = 0$
B. $\rightarrow 0 < \xi_i \leq 1$
C. $\rightarrow 1 < \xi_i$

Οι ξ_i είναι γνωστές ως **μεταβλητές χαλαρότητας**
(**slack variables**)

- Ο στόχος της βελτιστοποίησης είναι τώρα διπτός
 - Μεγιστοποίηση περιθωρίου
 - Ελαχιστοποίηση του αριθμού των διανυσμάτων με $\xi_i > 0$
 Δηλαδή,

$$J(\underline{w}, w_0, \underline{\xi}) = \frac{1}{2} \|\underline{w}\|^2 + C \sum_{i=1}^N I(\xi_i)$$

όπου C σταθερά και

$$I(\xi_i) = \begin{cases} 1 & \xi_i > 0 \\ 0 & \xi_i = 0 \end{cases}$$

- $I(\cdot)$ δεν είναι παραγωγίσιμη. Στην πράξη, χρησιμοποιούμε μία προσέγγιση

- $J(\underline{w}, w_0, \underline{\xi}) = \frac{1}{2} \|\underline{w}\|^2 + C \sum_{i=1}^N \xi_i$

- Εργαζόμενοι όπως και προηγουμένως παίρνουμε

➤ ΚΚΤ συνθήκες

$$(1) \underline{w} = \sum_{i=1}^N \lambda_i y_i \underline{x}_i$$

$$(2) \sum_{i=1}^N \lambda_i y_i = 0$$

$$(3) C - \mu_i - \lambda_i = 0, i = 1, 2, \dots, N$$

$$(4) \lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1 + \xi_i] = 0, i = 1, 2, \dots, N$$

$$(5) \mu_i \xi_i = 0, i = 1, 2, \dots, N$$

$$(6) \mu_i, \lambda_i \geq 0, i = 1, 2, \dots, N$$

➤ Το σχετικό δυϊκό πρόβλημα

$$\text{Μεγιστοποίησε } \lambda - \left(\sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j \underline{x}_i^T \underline{x}_j \right)$$

υπό τις προϋποθέσεις

$$0 \leq \lambda_i \leq C, \quad i = 1, 2, \dots, N$$

$$\sum_{i=1}^N \lambda_i y_i = 0$$

➤ **Σχόλιο:**

Η μόνη διαφορά με την περίπτωση των διαχωρίσιμων κλάσεων είναι η ύπαρξη του C στους περιορισμούς.